



UNIVERSIDAD NACIONAL DE COLOMBIA
SEDE MEDELLÍN

PLANEACION GEOSTADISTICA DE UN DEPÓSITO DE CARBÓN
– MINA CERREJÓN-

MONOGRAFÍA PARA OPTAR POR EL TÍTULO
MAGISTER EN INGENIERÍA – RECURSOS MINERALES

RAFAEL IGNACIO MACHADO SERRANO

LUIS HERNÁN SÁNCHEZ ARREDONDO
DIRECTOR

UNIVERSIDAD NACIONAL DE COLOMBIA
FACULTAD DE MINAS
MEDELLÍN, COLOMBIA

2017

AGRADECIMIENTOS

En primer lugar, doy infinitas gracias a Dios, por protegerme en todo momento, por haberme acompañado y guiado a lo largo de este proyecto.

A CERREJÓN, Muchas gracias por todo el apoyo que me brindo para realizar este trabajo. Agradezco sinceramente la ayuda otorgada por todos los profesores del postgrado, por su valioso tiempo, por su apoyo a si como por la sabiduría que me trasmitieron en el desarrollo de este proceso.

Agradezco especialmente al Profesor Luis Hernán Sánchez, quien fue un excelente tutor y director de tesis, quien estuvo siempre brindándome su apoyo y confianza en mi trabajo y su gran capacidad para guiar mis ideas ha sido un aporte invaluable.

Doy gracias también a mis compañeros de maestría por la amistad y ayuda en este proceso. Finalmente, doy gracias de todo corazón a mi familia por el inmenso apoyo entregado, a mi esposa por todo su amor, dedicación y paciencia en este proceso.

Gracias...

DEDICATORIA

Es de gran satisfacción y felicidad finalizar hoy una etapa más en mi vida, cumplir una nueva meta y ver el fruto de un gran esfuerzo, es por eso por lo que quiero dedicar este trabajo principalmente a Dios, por ser el dueño de todo, por permitirme el haber llegado hasta este momento tan importante de mi formación profesional.

A mi pequeño Juan Esteban, hijo eres la principal motivación de mi vida.

RESUMEN

La planeación minera del carbón en el cerrejón se ha desarrollado empleando métodos de estimación tradicional como el inverso de la distancia para la estimación de recursos y de variables de calidad. Este tipo de método no tienen en cuenta el error en la estimación y por ende tienen mayor incertidumbre. Teniendo en cuenta que la estimación de recursos es la base de los planes mineros utilizados para establecer las metas de producción y como motivación adicional de utilizar métodos geoestadísticos para estimar en un depósito de carbón, se realizó una comparación entre el método de estimación actual inverso de la distancia, kriging ordinario, intervalos de confianza y simulación con secuencial condicional gaussiano. La zona de estudio fue en el área centro en el tajo 100 con datos del manto AB, la información fue ajustada con un factor para la protección de los datos e igualmente los resultados reales de la zona excavada con la cual se comparó.

El análisis se dividió en dos partes: la primera orientada a variables de calidad donde se estudiaron el poder calorífico (Btu/lb), cenizas (%) y humedad total (%), estimando el poder calorífico con inverso de la distancia con media y desviación estándar de $12,219 \pm 485$ Btu/lb, kriging ordinario de bloques con $12,342 \pm 301$ Btu/lb, simulación condicional gaussiana con $12,144 \pm 195$ Btu/lb y se comparó con el valor real 12,046 Btu/lb, por lo cual la mejor aproximación se obtuvo con la simulación condicional gaussiana y adicionalmente es la que mejor representa el comportamiento del poder calorífico del manto AB.

El segundo análisis se hizo utilizando el espesor(m) del manto de carbón, como variable crítica para estimar recursos recuperables. Se estimó por inverso de la distancia con media de 4,43m, kriging ordinario de bloques con media 4,26m e intervalos de confianza con valor pesimista de 3,53m, promedio de 4,26m y optimista de 5,53m.

La conclusión, a la que se llegó luego de ambos análisis, es que utilizar la geoestadística es la mejor técnica para tener una estimación más confiable y una mejor representatividad en el comportamiento de las variables en los mantos de carbón.

Palabras claves:

Geoestadística, Variables de calidad de carbón, Kriging, Intervalos de confianza, Simulación condicional Gaussiana

ABSTRACT

Coal mining in El Cerrejon has been developed using traditional estimation methods as the inverse of the distance for estimating resources and quality variables. This type of method does not take into account the error in the estimation and therefore has greater uncertainty. Taking into account that the estimation of resources is the basis of the mining plans used to establish the production goals and as an additional motivation to use geostatistical methods to estimate a coal deposit, a comparison was made between the current reverse estimation method of the distance, ordinary kriging, confidence intervals and simulation with sequential Gaussian conditional. The study area was in the center area in pit 100 with data from the seam AB the information was adjusted with a factor for the protection of the data and also the actual results of the excavated area with which it was compared.

The analysis was divided into two parts: the first one oriented to quality variables where the calorific power (Btu/lb), ash and total humidity were studied estimating the calorific power with inverse of the distance with mean and standard deviation of 12,219 +/- 485 Btu/lb ordinary kriging of blocks with 12,342 +/-301 Btu/ lb , conditional simulation Gaussian with 12,144 +/- 195 Btu/lb and was compared with the real value 12,046 Btu / lb, so the best approximation was obtained with the conditional Gaussian simulation and additionally is the one that best represents the behavior of the caloric power of seam AB.

The second Analysis was done using the thickness (m) of the carbon seam, as a critical variable to estimate recoverable resources. It was estimated by the inverse of the distance with average of 4.43m, ordinary kriging of blocks with average 4 and confidence intervals with pessimistic value of 3.53m, average of 4.26m and optimistic of 5.53m

The conclusion after both analysis, is that to use the geostatistics is the best technique to have a more reliable estimate and a better representation of the behavior of the variables in the carbon seams.

Keywords:

Geostatistics, Coal quality variables, Kriging, Confidence intervals, condicional Gaussian simulation

CONTENIDO

ÍNDICE DE FIGURAS	8
ÍNDICE DE TABLAS	10
1. INTRODUCCION	11
2. OBJETIVOS:	13
2.1 OBJETIVO GENERAL:	13
2.2 OBJETIVOS ESPECIFICOS:	13
3. METODOLOGÍA.....	14
4. MARCO TEÓRICO Y ESTADO DEL ARTE.....	15
4.1 VARIABLES REGIONALIZADAS(VR):	15
4.2 ANALISIS EXPLORATORIO DE DATOS.....	16
4.3 ESTIMACIÓN LOCAL.....	16
4.3.1 Inverso de la distancia:	16
4.3.2 Estimación con kriging:	17
4.4 GEOESTADISTICA NO LINEAL.....	19
4.4.1 Transformación gaussiana.....	19
4.4.2 Intervalos de confianza.	20
4.4.3 Secuencial gaussiano.....	21
4.5 ESTADO DEL ARTE	22
5.CASO DE ESTUDIO.	25
5.1 DATOS GENERALES.....	25
5.1.1 Ubicación:	25
5.1.2 Operación:	25
5.2 VARIABLES DE CALIDAD.....	26
5.2.1 Análisis exploratorio de datos.....	26
5.2.2 Análisis de anisotropías.....	38
5.2.3 Variograma.....	40
5.2.4 Estimación	46
5.3 Recursos In situ:	55

5.3.1 Análisis exploratorio de datos	55
5.3.2 Variograma	56
5.3.3 Estimación.	60
5.3.4 Comparación entre los métodos de estimación de Recursos In Situ	65
6.CONCLUSIONES	66
7. RECOMENDACIONES	67
8. BIBLIOGRAFÍA	68

ÍNDICE DE FIGURAS

Figura 1 .Construcción gráfica de la anamorfosis Gaussiana.	20
Figura 2. Ubicación del Cerrejón.	25
Figura 3. Ubicación espacial de los datos de poder calorífico.....	27
Figura 4. Grafico Q-Q de poder calorífico.....	28
Figura 5. Histograma de poder calorífico.....	29
Figura 6. Distribución espacial de los datos de cenizas para manto AB.	30
Figura 7. Grafico Q-Q de la variable ceniza	31
Figura 8. Histograma de la variable Ceniza.....	32
Figura 9. Grafico Q-Q de la variable ceniza transformada.	33
Figura 10. Ubicación geoespacial de los datos de humedad.	34
Figura 11. Grafico Q-Q de humedad.	35
Figura 12. Histograma de humedad sin transformar.	36
Figura 13. Grafico Q-Q de humedad transformada.	37
Figura 14. Análisis de la anisotropía de la variable poder calorífico.....	38
Figura 15. Análisis de la anisotropía de la variable ceniza.	39
Figura 16. Análisis de la anisotropía de la variable humedad.	39
Figura 17. Variograma experimental y teóricos ajustados poder calorífico.	41
Figura 18. Validación cruzada de poder calorífico.....	42
Figura 19. Variograma experimental y teóricos ajustados ceniza.	43
Figura 20. Validación cruzada de ceniza transformada.....	44
Figura 21. Variograma experimental y teóricos ajustados humedad transformada.	45
Figura 22. Validación cruzada.	46
Figura 23. Inverso de la distancia al cuadrado de poder calorífico.	47
Figura 24. Inverso de la distancia de ceniza.	48
Figura 25. Inverso de la distancia de humedad.....	48
Figura 26. Estimación de poder calorífico por kriging ordinario.....	49
Figura 27. Estimación de ceniza kriging lognormal.	50
Figura 28. Estimación de humedad por kriging lognormal.	50
Figura 29. Coeficientes normalizados del polinomio de hermita.	51
Figura 30. Histograma de poder calorífico normalizado.	51
Figura 31. Variograma teórico ajustado de poder calorífico gaussiano.....	52
Figura 32. Simulación secuencial gaussiana de poder calorífico.	53

Figura 33. Grado-proporción del poder calorífico para los diferentes métodos de estimación.	54
Figura 34. Histograma de espesor normalizado.	55
Figura 35. Grafica Q-Q de espesor normalizado.	56
Figura 36. Análisis Variográfico de espesor.	57
Figura 37. Variograma experimental ajustado de espesor mAB.	58
Figura 38. Validación cruzada del modelo teórico para la variable espesor.	59
Figura 39. Estimación del espesor por inverso de la distancia al cuadrado.	60
Figura 40. Estimación de espesor por kriging ordinario.	61
Figura 41. Polinomio de hermita de a variable espesor gaussiano.	61
Figura 42. Histograma de la variable espesor gaussiano.	62
Figura 43. Variograma teórico ajustado de la variable espesor gaussiano.	62
Figura 44. Estimación de espesor por intervalos de confianza ideal.	63
Figura 45. Estimación de espesor por intervalos de confianza caso optimista.	64
Figura 46. Estimación de espesor por intervalos de confianza caso pesimista.	64
Figura 47. Comparación entre métodos de estimación.	65

ÍNDICE DE TABLAS

Tabla 1. Estadística básica de las variables de calidad.	26
Tabla 2. Matrix de correlación.	27
Tabla 3. Resultado de la validación de poder calorífico.	42
Tabla 4. Resultado de la validación de ceniza.	43
Tabla 5. Resultado de la validación de humedad.	45
Tabla 6. comparación de resultados de estimaciones de poder calorífico.	53
Tabla 7. Estadística básica.	55
Tabla 8. Resultado de la validación de espesor.	58

1. INTRODUCCION

La industria minera está pasando por una situación difícil debido a todas las restricciones ambientales y sociales que van en aumento, esto puede conllevar a que un mineral no sea atractivo para su explotación. Por lo tanto, minimizar la incertidumbre generada en el modelo geológico es el reto de toda compañía minera, para tomar decisiones acertadas.

Basado en la premisa de lograr la menor incertidumbre geológica posible en los proyectos mineros, surgen nuevas técnicas para estimar Recursos In Situ y variables/atributos del mineral o del depósito como la geoestadística, que es una herramienta que permite tener estimaciones más acertadas porque tiene en cuenta la variabilidad del depósito. El método tradicional de cálculo en la mina El Cerrejón, es el inverso de la distancia y la geoestadística cuenta con diferentes técnicas de estimación y simulación. La gran parte de los estudios geoestadísticos han sido realizados en depósitos metálicos donde es más difícil ubicar el mineral o en yacimientos petroleros. Sin embargo, estas técnicas se han implementado en muchas otras disciplinas y se hace modelación y simulación de variables ambientales, ruido, datos geotécnicos, etc.

En la minería del carbón a diferencia de la metálica el mineral se encuentra fácilmente, pues al perforar se diferencia claramente entre carbón y estéril, sin embargo, para modelar las variables y estimar volumen, hay que tener en cuenta el buzamiento y espesor, y para el análisis de la calidad, hay que tener en cuenta el poder calorífico, la humedad, la ceniza, el material volátil, los sulfuros, el azufre y el sodio, entre otros. Por lo tanto, para modelar estas variables se requiere interpolar los datos de las perforaciones.

Las variables por analizar de los mantos de carbón cumplen con el requerimiento de un estudio geoestadístico de ser variables aleatorias y con continuidad espacial. La diferencia a la hora de iniciar un estudio es tener claro que un depósito metálico el cuerpo mineralizado puede corresponder a una sola formación y en un depósito de carbón cada manto es independiente y por ende se debe estudiar por separado. En este caso, los recursos recuperables del modelo geológico estarán determinadas por la sumatoria de las toneladas de todos los mantos del depósito y el promedio de las variables de calidad.

La modelización geoestadística de un manto de carbón para la evaluación de riesgos de los recursos recuperables, demuestra que se obtiene una evaluación más realista de este cuando la incertidumbre de los parámetros del modelo del semivariograma se tiene en cuenta (Pardo-Igúzquiza, Dowd, Baltuille, & Chica-Olmo, 2013).

La evaluación de las características de calidad de un depósito se puede hacer a través de la distribución espacial y la incertidumbre de las variables de calidad con Simulación Secuencial Gaussiano y los modelos simulados que se pueden incorporar en la planificación minera y la programación (Ersoy & Yünsel, 2006).

2. OBJETIVOS:

2.1 OBJETIVO GENERAL:

- Estimar en la mina el Cerrejón, para un tajo piloto los Recursos recuperables y la calidad por métodos de geoestadística no lineal.

2.2 OBJETIVOS ESPECIFICOS:

- Estimar las Recursos In Situ globales utilizando intervalos de confianza.
- Estimar las variables de calidad; poder calorífico, humedad y cenizas, con el método de simulación condicionada “secuencial gaussiano”.
- Conciliar los resultados obtenidos por método el convencional Kriging ordinario de bloques, la simulación condicionada (Secuencial Gaussiano) y los valores reales.

3. METODOLOGÍA

Los datos utilizados para la elaboración de este trabajo son suministrados por la empresa Cerrejón Limited y corresponde al manto AB de la zona sur del complejo carbonífero, el área de estudio no ha sido minada en su totalidad, pero se conocen datos reales de lo extraído.

En este estudio del manto AB, se analizaron las variables poder calorífico (Btu/lb), cenizas (%), humedad (%) y espesor (m). Se usaron técnicas de estimación tradicional con el método de interpolación del inverso de la distancia, la estimación geoestadística se desarrolló con Kriging Ordinario de Bloques, los procedimientos del Intervalo de Confianza y Simulación Secuencial Gaussiana. El software utilizado para realizar el estudio fue ISATIS (versión 2017) de Geovariances.

Para cada variable se realizó un análisis exploratorio de los datos, con identificación de anisotropías y cálculo del variograma experimental, luego se ajustó el variograma teórico y se establecieron vecindades para finalmente validar los modelos. Para Intervalos de confianza y secuencial gaussiano se realizó la transformación gaussiana de poder calorífico y espesor.

La malla de estimación utilizada fue de 100 X 100 metros y se hizo en 2 dimensiones porque las relaciones de espesor versus longitud de los mantos de carbón no hacen representativo un análisis en el eje vertical.

Los resultados obtenidos fueron analizados estadísticamente y se realizó una conciliación entre las diferentes técnicas de estimación y datos reales.

Por protección de la información los datos utilizados en todo el estudio han sido ajustados por lo cual no representan los datos de la empresa, pero sirven para mostrar la metodología.

4. MARCO TEÓRICO Y ESTADO DEL ARTE

La geoestadística es una rama de la estadística que se encarga de estudiar fenómenos regionalizados, es decir, variables conocidas como "*variables regionalizadas*" que están distribuidas en el espacio y que miden ciertos atributos en el espacio. Fue inventada por Georges Matheron en 1962, desde entonces ha tenido un gran desarrollo y aplicación en la ingeniería por representar mejor los fenómenos al tener en cuenta la variabilidad de los datos en el espacio.

Para realizar un análisis geoestadístico se debe determinar el dominio o campo de estudio, por esto es importante conocer el fenómeno geológico al que pertenecen los datos.

4.1 VARIABLES REGIONALIZADAS(VR):

Son todas aquellas variables que representan propiedades o atributos que se extienden en el espacio y presentan una cierta continuidad. Se pueden definir en cada punto del espacio y también en una superficie (2D) o en un volumen (3D). La superficie o el volumen sobre el cual se considera la variable regionalizada se denomina soporte. Esta noción es esencial debido a la dependencia que existe entre el soporte y la distribución estadística de los valores, conocida como efecto de soporte(Emery, 2007).

Momentos de distribución VR(Díaz Viera, 2002):

Las variables aleatorias regionalizadas están determinadas por $Z(\underline{x})$ y los momentos de la distribución son:

- El momento de primer orden de $Z(\underline{x})$ es la esperanza matemática definida como:

$$m(\underline{x}) = E[Z(\underline{x})]$$

- Los momentos de segundo orden considerados en geoestadística son:

- i) La varianza de $Z(\underline{x})$

$$\sigma^2(\underline{x}) = Var[Z(\underline{x})] = E\left[\{Z(\underline{x}) - m(\underline{x})\}^2\right]$$

- ii) La covarianza de dos variables aleatorias $Z(\underline{x}_i)$ y $Z(\underline{x}_j)$ definida como:

$$C(\underline{x}_i, \underline{x}_j) = E\left[\left\{Z(\underline{x}_i) - m(\underline{x}_i)\right\}\left\{Z(\underline{x}_j) - m(\underline{x}_j)\right\}\right]$$

Esta función es también conocida como función de auto covarianza.

iii) El semivariograma $\gamma(\underline{x}_i, \underline{x}_j)$ que se define como:

$$2\gamma(\underline{x}_i, \underline{x}_j) = Var\left[Z(\underline{x}_i) - Z(\underline{x}_j)\right]$$

$$\gamma(\underline{x}_i, \underline{x}_j) = \frac{1}{2} E\left[\left\{Z(\underline{x}_i) - Z(\underline{x}_j)\right\}^2\right]$$

Se debe notar que tanto la varianza como el variograma son siempre positivos, mientras que la covarianza puede tomar valores negativos.

4.2 ANALISIS EXPLORATORIO DE DATOS

Consiste en estudiar una o varias variables regionalizadas con el objetivo de analizar con estadística clásica la cantidad, la calidad y la ubicación de los datos, definir la zona de estudio y en caso de requerirse hacer sub-zonas, e identificar valores atípicos que puedan causar problemas en la estimación local (Emery, 2007).

4.3 ESTIMACIÓN LOCAL

La estimación local permite establecer el valor de una variable con los datos disponibles dentro de un dominio definido. Los métodos de estimación corresponden a diferentes técnicas de interpolación.

4.3.1 Inverso de la distancia:

Este método asigna un valor inversamente proporcional de la distancia al sitio donde se desea hacer la estimación, si el valor asignado es bajo entonces la distancia elevada a esa potencia es 1 y entonces a todos los datos se les asigna el mismo valor, si por el contrario

el valor asignado es muy alto, los valores elevados a esa potencia se volverán muy pequeños y el método se convertirá en el vecino más cercano. Así que se recomienda para casos de estimación de recursos mineros emplear un factor de potencia de 2.

4.3.2 Estimación con kriging:

Este método permite estimar la variable regionalizada en un lugar no muestreado, a partir de los datos que se encuentren dentro de una vecindad. La definición de esta vecindad (radio, orientación, número de datos a buscar) toma en cuenta la continuidad espacial de la variable regionalizada y el diseño de la malla de muestreo, lo que se realiza en la etapa del estudio exploratorio y Variográfico. El estimador es una combinación lineal ponderada de los datos y, por lo tanto, el problema del Kriging se reduce a calcular los valores de los ponderadores que permitan obtener una estimación insesgada y con la mejor precisión posible (Isabel, 2010).

Existen diferentes tipos de kriging como kriging simple, ordinario, lognormal, entre otros. En este trabajo solo se profundizará sobre el kriging ordinario y el lognormal que fueron los que se utilizaron.

Kriging Ordinario (Emery, 2007)

- **Hipótesis**

Se supone ahora que la variable regionalizada es la realización de una función aleatoria Z estacionaria tal que:

$$\begin{cases} \forall \mathbf{x} \in V, E[Z(\mathbf{x})] = m \text{ desconocida} \\ \forall \mathbf{x}, \mathbf{x} + \mathbf{h} \in V, \text{cov}[Z(\mathbf{x} + \mathbf{h}), Z(\mathbf{x})] = C(\mathbf{h}) \end{cases}$$

donde V representa la vecindad de kriging.

- **Determinación del estimador**

Las etapas del kriging dan:

- Linealidad: se asegura esta restricción al tomar como estimador en X_0

$$Z^*(\mathbf{x}_0) = a + \sum_{\alpha=1}^n \lambda_{\alpha} Z(\mathbf{x}_{\alpha})$$

- Insesgo: el valor esperado del error de estimación es

$$E[Z^*(\mathbf{x}_0) - Z(\mathbf{x}_0)] = a + \sum_{\alpha=1}^n \lambda_{\alpha} \underbrace{E[Z(\mathbf{x}_{\alpha})]}_{=m} - \underbrace{E[Z(\mathbf{x}_0)]}_{=m} = a + \left(\sum_{\alpha=1}^n \lambda_{\alpha} - 1 \right) m$$

- Como se desconoce el valor de la media m , este valor esperado es nulo si:

$$a=0 \text{ y } \sum_{\alpha=1}^n \lambda_{\alpha} = 1.$$

- La igualdad sobre la suma de los ponderadores asegura que, en el caso en que todos los datos son iguales a una misma constante, el valor estimado restituirá esta constante.
- Optimalidad: como en el caso del kriging simple, la varianza del error de estimación es

$$\text{var}[Z^*(\mathbf{x}_0) - Z(\mathbf{x}_0)] = \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} C(\mathbf{x}_{\alpha} - \mathbf{x}_{\beta}) + C(\mathbf{0}) - 2 \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{x}_{\alpha} - \mathbf{x}_0)$$

- Se necesita minimizar esta expresión bajo la condición del insesgo, que impone que la suma de las incógnitas es igual a 1. Esto se logra introduciendo una incógnita adicional llamada multiplicador de Lagrange, que denotaremos como μ . Se escribe:

$$\begin{aligned} & \text{var}[Z^*(\mathbf{x}_0) - Z(\mathbf{x}_0)] \\ &= C(\mathbf{0}) + \sum_{\alpha=1}^n \sum_{\beta=1}^n \lambda_{\alpha} \lambda_{\beta} C(\mathbf{x}_{\alpha} - \mathbf{x}_{\beta}) - 2 \sum_{\alpha=1}^n \lambda_{\alpha} C(\mathbf{x}_{\alpha} - \mathbf{x}_0) + 2\mu \underbrace{\left(\sum_{\alpha=1}^n \lambda_{\alpha} - 1 \right)}_{=0} \end{aligned}$$

y se minimiza la función de las $n+1$ variables $\lambda_1, \dots, \lambda_n, \mu$. Calculando las $n+1$ derivadas parciales de esta función y luego anulándolas, se obtiene el sistema:

$$\begin{cases} \frac{\partial}{\partial \lambda_{\alpha}} = 0 : \sum_{\beta=1}^n \lambda_{\beta} C(\mathbf{x}_{\alpha} - \mathbf{x}_{\beta}) + \mu = C(\mathbf{x}_{\alpha} - \mathbf{x}_0) & \forall \alpha = 1 \dots n \\ \frac{\partial}{\partial \mu} = 0 : \sum_{\alpha=1}^n \lambda_{\alpha} = 1 & \text{(condición de insesgo)} \end{cases}$$

Este sistema contiene una incógnita y una ecuación más que el sistema de kriging simple. Se puede escribir en notación matricial:

$$\begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_1) & \cdots & C(\mathbf{x}_1 - \mathbf{x}_n) & 1 \\ \vdots & & \vdots & \vdots \\ C(\mathbf{x}_n - \mathbf{x}_1) & \cdots & C(\mathbf{x}_n - \mathbf{x}_n) & 1 \\ 1 & \cdots & 1 & 0 \end{pmatrix} \begin{pmatrix} \lambda_1 \\ \vdots \\ \lambda_n \\ \mu \end{pmatrix} = \begin{pmatrix} C(\mathbf{x}_1 - \mathbf{x}_0) \\ \vdots \\ C(\mathbf{x}_n - \mathbf{x}_0) \\ 1 \end{pmatrix}$$

Kriging lognormal (Emery, 2007)

Este método consiste en aplicar kriging a una transformada (no lineal) de la variable Z , luego en volver a esta variable. Esta etapa de transformación de vuelta no es trivial, pues requiere introducir correcciones para que el estimador final no tenga sesgo. Por ejemplo, si la transformada logarítmica tiene una distribución Gaussiana, se obtiene el llamado kriging lognormal:

$$Z^*(x_0) = \exp \left\{ \sum_{\alpha=1}^n \lambda_{\alpha} \ln[Z(x_{\alpha})] + \frac{\sigma_{KO}^2(x_0)}{2} + \mu \right\}$$

donde $\sigma_{KO}^2(x_0)$ es la varianza de kriging ordinario de $\ln[Z(X_0)]$ y μ es el multiplicador de Lagrange introducido en el sistema de kriging ordinario. Esta expresión muestra que el kriging lognormal de la variable Z coincide con la exponencial del kriging de $\ln(Z)$. El regreso a la variable inicial (Z) necesita introducir un factor correctivo $\sigma_{KO}^2(x_0)/2 + \mu$, sin el cual la estimación Z^* sería sesgada.

4.4 GEOESTADISTICA NO LINEAL

En este grupo se encuentran las técnicas geoestadísticas que requieren una transformación previa de los datos para luego analizarlos, el kriging lognormal hace parte de este grupo, sin embargo, en esta sección se explican las técnicas que requieren de una transformación gaussiana.

4.4.1 Transformación gaussiana(emery, 2007)

Es poco frecuente que la variable estudiada pueda ser considerada como Gaussiana: a menudo, la distribución univariada (histograma de los valores medidos) es asimétrico y no es compatible con un modelo Gaussiano. Una transformación – llamada Anamorfosis – es necesaria para convertirla en una distribución Gaussiana. Gráficamente, la transformación consiste en deformar el histograma de los datos en un histograma Gaussiano estándar, es decir, de media 0 y varianza 1 (Figura 1).




Figura 1 .Construcción gráfica de la anamorfosis Gaussiana.

Fuente: Tomado de (Emery, 2007)

4.4.2 Intervalos de confianza.

Es un método geoestadístico no lineal, que requiere transformar los datos en una distribución normal equivalente, de esta forma se obtienen los intervalos de confianza para una variable normal y se revierte la transformación de los datos para encontrar los intervalos de confianza de los datos originales (Roth & Armstrong, n.d.).

La teoría expuesta por Chris Roth y Margaret Armstrong es referenciada por (Isabel, 2010): Si se representa una variable de interés como $Z(x)$ la estimación de la misma por un método como el Kriging se designa como $Z^K(x)$ y la desviación estándar del kriging como K . El error en la estimación corresponde a la diferencia entre el valor real y el estimado $Z(x) - Z^K(x)$. Al obtener el intervalo de confianza estándar se asume que el error de la estimación es normalmente distribuido, en este caso el intervalo de confianza para una probabilidad del 95% se da por la expresión:

$$\Pr(Z^K(x) - 2\sigma_K < Z(X) < Z^K(x) + 2\sigma_K)$$

Donde Pr es la probabilidad media. En general la distribución normal del error es bastante rara debido a la distribución aleatoria de los datos, lo que genera inconsistencias en el manejo de la información.

Consistentes con lo anterior, el intervalo de confianza de una distribución lognormal, $Z(x)$ puede ser obtenido primero transformando dicha distribución a normal $Y(x) = \log(Z(x))$ y luego en esta distribución normal utilizando dos desviaciones estándar.

$$\Pr(Y^K(x) - 2\sigma_K < Y(x) < Y^K(x) + 2\sigma_K) = 95\%$$

Devolviéndonos en la transformación la expresión anterior queda:

$$\Pr(e^{Y^K(x) - 2\sigma_K} < Z(x) < e^{Y^K(x) + 2\sigma_K}) = 95\%$$

El volver a las condiciones iniciales antes de la transformación implica pasar de las condiciones simétricas a unas asimétricas (lognormales). Esta es en realidad una visión simplista de suponer que las muestras son exactamente lognormales. En la práctica las muestras pueden ser sesgadas, pero no encajan dentro de una distribución lognormal, lo que lleva a obtener intervalos de confianza para una distribución arbitraria.

Para el estudio realizado se utilizó intervalos de confianza en la variable espesor para comparar con los resultados del kriging.

4.4.3 Secuencial gaussiano.

El secuencial es el método más sencillo para la simulación de un campo Gaussiano multivariante. Cada valor se simula de forma secuencial de acuerdo con su función de distribución normal condicional acumulativa, que debe ser determinada en cada ubicación a simular. Los datos de acondicionamiento comprenden todos los datos originales y todos los valores previamente simulados dentro de la vecindad del punto que está siendo simulado (Webster & Oliver, 2008).

Algoritmo Secuencial (Emery, 2007)

Supongamos que se busca simular una función aleatoria multi-Gaussiana Y de media 0 y variograma $\gamma(h)$ en los sitios $\{u_1, \dots, u_n\}$ del espacio, condicionada a los datos Gaussianos disponibles en los sitios $\{x_1, \dots, x_n\}$. El algoritmo secuencial procede de la siguiente manera.

Para cada sitio $u_i (i = 1, \dots, m)$:

Realizar el kriging de $Y(u_j)$ a partir de los datos condicionantes $\{Y(x_1), \dots, Y(x_n)\}$ y de los valores previamente simulados $\{Y(u_1), \dots, Y(u_{i-1})\}$. Como resultado, se obtiene un valor estimado $Y^*(u_j)$ y una desviación estándar $\sigma^*(u_j)$.

Simular un valor Gaussiano, cuya media es igual a $Y^*(u_i)$ y cuya desviación estándar es igual a $\sigma^*(u_i)$:

$$Y(u_i) = Y^*(u_i) + \sigma^*(u_i) N_i,$$

donde N_i es una variable aleatoria Gaussiana de media 0 y varianza 1, independiente de $N_1 \dots N_{i-1}$ y de los datos originales $Y(x_1), \dots, Y(x_n)$.

Así pues, en la i -ésima etapa, se simula el valor Gaussiano en el sitio u_i y se agrega el valor simulado a los datos condicionantes para simular los sitios siguientes, de donde viene el nombre "secuencial". En teoría, se requiere usar un kriging simple (de media conocida = media de la variable Gaussiana = 0).

4.5 ESTADO DEL ARTE

Los estudios de geoestadística aplicada a la minería del carbón son pocos en comparación con las publicaciones realizadas en minería de depósitos metálicos, sin embargo, los resultados que se han obtenido son bastante buenos y demuestran que la geoestadística es completamente aplicable a la minería de carbón.

La universidad de Hacettepe de Turquía (A Erhan Tercan & Ihsan, 2001), abordan un caso de estudio sobre la estimación global de las reservas de lignito y las variables consideradas son tonelaje, espesor y parámetros de calidad como contenido de cenizas, azufre, y el poder calorífico. Las estimaciones globales de estas variables, junto con límites de confianza del 95% se obtienen utilizando el principio de aproximación de la estimación global. Este estudio se continuo por parte de los autores y en 2005 para el mismo caso de estudio se realizó la evaluación de la incertidumbre asociada a las curvas de la calidad de tonelaje de lignito. Los mantos se decidieron en 180 paneles con dimensiones 200 x 200m y la calidad de cada panel se estimó por simulación condicional; secuencial gaussiana, teniendo en cuenta las variables poder calorífico, contenido de cenizas y azufre.

La universidad de Cukurova de Turquía (Ersoy & Yünsel, 2006), realizaron una publicación sobre simulación condicional geoestadística para la evaluación de las características de calidad de un depósito de lignito en ese país. La distribución espacial y la incertidumbre de las variables de calidad en el área de estudio se analizaron basado en Simulación Secuencial Gaussiano y los modelos simulados se pueden incorporar en la planificación minera y la programación.

Otro caso de estudio de referencia fue el realizado en el depósito de carbón en Kalimantan (Borneo), Indonesia (Nur & Koike, 2008a). Los datos se correlacionaron espacialmente en el mismo o sobre diferentes mantos, se utilizan principalmente las técnicas multivariantes (Cokriging ordinario y Cokriging factorial) y los resultados de las estimaciones espaciales se compararon con los obtenidos utilizando una técnica univariada (kriging ordinario). La segunda publicación se basa en la evaluación de la incertidumbre de las toneladas de carbón por el modelado espacial de distribución de los mantos y calidad del carbón, este estudio demuestra que la incertidumbre de la acumulación de carbón está relacionada con la distribución de los mantos y que los patrones de variabilidad espacial de calidades de carbón se oponen entre el contenido de cenizas y azufre total: esta diferencia podría haber sido causado por los controles geológicos (Nur & Koike, 2008b).

Ersoy, A.y Yünsel, T.Y. publicaron en 2009 acerca de la evaluación de las variables de calidad de lignito usando simulación secuencial gaussiana en un depósito en Adana-Turquía. Se mapeo los límites máximos / mínimos para los valores de calidad y se obtuvo un modelo para la incertidumbre en la distribución espacial de los parámetros de calidad.

En 2010, Mehmet Ali Hindistan, Abdullah Erhan Tercan y Bahtiyar Ünver hicieron un trabajo en control geoestadístico de la calidad del carbón en la minería de tajo largo. Estimaron el poder calorífico promedio de los bloques dentro de los paneles de producción utilizando kriging.

El año 2013 se publicaron 2 estudios, el primero (Ertunç et al., 2013) publicó sobre la estimación geoestadística de variables de calidad del carbón mediante el uso de covarianza kriging con restricciones de coincidencia. Es una técnica que desarrolla un sistema híbrido que considera la exactitud local en kriging y la conservación de la variabilidad espacial en la simulación estocástica.

Después (A E Tercan & Sohrabian, 2013) la universidad de Hacettepe de Turquía, realizó una técnica geoestadística que se basa en derivar componentes independientes de datos multivariados y simular cada uno de forma independiente. La aplicación muestra que las estadísticas de entrada, como media, histograma, variograma y coeficiente de correlación para las variables de calidad se reproducen bien y la simulación de componentes independientes pueden ser utilizada en la simulación de datos multivariados.

En 2015, se realizó un Mapeo de la calidad del carbón utilizando la simulación estocástica y la transformación isométrica con una aplicación a un depósito de Lignito en Texas, de este estudio se concluye que la producción de mapas de calidad para la aplicación de la transferencia de información y la simulación secuencial permiten un método de modelado matemáticamente sólido, que proporciona presentaciones de atributos en mapas individuales o de probabilidad que combinan dos o más atributos(Olea & Luppens, 2015).

Las revisiones muestran a Turquía como el país que ha sido pionero en estos estudios, sin embargo, en los últimos años ha crecido el interés de aplicar las técnicas geoestadística a carbón en diferentes parte del mundo. Con respecto, al caso de estudio presentado en este trabajo se busca realizar el primer estudio geoestadístico aplicado a un depósito de carbón en Colombia.

5.CASO DE ESTUDIO.

5.1 DATOS GENERALES(CERREJÓN, 2017).

5.1.1 Ubicación:

El depósito carbonífero el Cerrejón está ubicado en zona norte de Colombia, en el departamento de La Guajira (ver figura 2). El área de concesión de este proyecto se encuentra entre los municipios de Albania, Hatonuevo y Barrancas.



Figura 2. Ubicación del Cerrejón.

Fuente: www.google.com Fecha: 24-11-2017

5.1.2 Operación:

Cerrejón es un complejo minero con una mina a cielo abierto de carbón térmico, la cual produce más de 32 millones de toneladas por año, un ferrocarril de 150 km de largo y un puerto marítimo de cargue directo capaz de recibir buques de hasta 180000 toneladas de capacidad

Aproximadamente el 70% del carbón minado es triturado inmediatamente y despachado en tren, el 30% restante es almacenado de acuerdo con su poder calorífico, contenido de cenizas y azufre para hacer mezclar y ajustar la calidad del carbón despachado.

En un momento dado el carbón producido es principalmente un producto sin lavar y triturado con valores típicos de poder calorífico de 10,600 Btu/lb GAR hasta 11,300 Btu/lb GAR.

5.2 VARIABLES DE CALIDAD.

Las variables de calidad que se van a analizar son poder calorífico (Btu/lb), Cenizas (%) y humedad total (%), las cuales son las de principal incidencia.

Para este estudio solo se analizan las variables del depósito y para la conciliación se tendrá en cuenta el ajuste por dilución en el minado.

5.2.1 Análisis exploratorio de datos.

Se hizo un análisis estadístico de los datos para cada variable con el fin de entender su comportamiento (ver tabla No.1).

ESTADÍSTICA BÁSICA - MANTO										
VARIABLE	Cantidad	Amplitud		Tendencia Central			Variabilidad		Estructura	
		Mínimo	Máximo	Media	Mediana	Varianza	Desviación Estandar	Variat.C	Skewness=0	Kurtosis=3
BTU	58	10533,20	12913,69	12337,30	12449,93	212443,54	460,92	0,04	-2,10	7,56
ASH	58	0,93	13,21	2,67	2,07	3,65	1,91	0,72	3,41	17,48
MOISTURE	58	8,29	21,09	12,49	11,90	4,71	2,17	0,17	2,09	7,98

Tabla 1. Estadística básica de las variables de calidad.

Fuente: Elaboración Propia.

De la tabla anterior se observa para la variable poder calorífica (BTU) la relación con la tendencia central de los datos mediana/media una diferencia de 1% frente a un valor ideal de normalidad. El coeficiente de variación es inferior al 10% % lo cual indica una baja variabilidad de los datos respecto a su tendencia central. A nivel de la estructura se presenta un valor de skewness o coeficiente de sesgo de -2.10, lo cual indica el desplazamiento de la gráfica de frecuencia es hacia la derecha con respecto al valor medio.

Para La ceniza y humedad la tendencia central es del 22% y 5% frente a un valor normal de normalidad respectivamente, se observa una alta variabilidad de los datos de ASH por tener un coeficiente de variabilidad mayor a 100% y con respecto al skewness que son mayores a cero por lo cual tienen desplazamiento hacia la izquierda en la gráfica de frecuencia.

La Tabla No.2 corresponde a la matriz de correlación entre las variables y se cumple la regla donde el poder calorífico del carbón es inversamente proporcional a la cantidad de ceniza y/o a la humedad que contenga el manto.

Matrix de correlacion			
VARIABLE	ASH	BTU	MOI
ASH	1,00	-0,84	0,35
BTU	-0,84	1,00	-0,78
MOI	0,35	-0,78	1,00

Tabla 2. Matrix de correlación.

Fuente: Elaboración Propia

A continuación, se muestra para cada variable el mapa de localización, histograma y grafico Q-Q:

La figura 3 corresponde a la ubicación geoespacial de los datos de poder calorífico de acuerdo con las perforaciones realizadas.




Figura 3. Ubicación espacial de los datos de poder calorífico.

Fuente: Elaboración propia

Los datos del grafico Q-Q (Figura 4) no muestran una tendencia de normalidad predominante.




Figura 4. Grafico Q-Q de poder calorífico.

Fuente: Elaboración propia

Sin embargo, el histograma de la figura 5 muestra los datos con una curva corrida a la derecha y con un dato aberrante de valor 10,500 Btu/lb.




Figura 5. Histograma de poder calorífico.

Fuente: Elaboración propia

La variable ceniza presenta un valor máximo en la zona media del área de estudio (ver figura 6).




Figura 6. Distribución espacial de los datos de cenizas para manto AB.

Fuente: Elaboración propia.

La figura 7, corresponde al grafico Q-Q y se observa el comportamiento lognormal de los datos al formar estos una curva con abertura hacia arriba. Esta variable requiere de una transformación de los datos para normalizarlos y se muestra mas adelante.




Figura 7. Grafico Q-Q de la variable ceniza

Fuente: Elaboración propia.

Revisamos el histograma para identificar el agrupamiento de los datos y valores aberrantes (ver figura 8):




Figura 8. Histograma de la variable Ceniza.

Fuente: Elaboración propia.

Para transformar los datos de logarítmicos a normales solo apliza la función $\ln(x)$ a todos los valores de ceniza y el resultado se puede observar nuevamente en el gráfico Q-Q de la figura 9:




Figura 9. Gráfico Q-Q de la variable ceniza transformada.

Fuente: Elaboración propia.

La última variable de calidad a analizar es la humedad, en la figura 10 se puede observar ubicación geoespacial de los datos.




Figura 10. Ubicación geoespacial de los datos de humedad.

Fuente: Elaboración propia.

El grafico Q-Q (ver figura 11) de la viable humedad indica que los datos son lognormal. Por lo anterior, se requiere hacer una transformación de los datos.




Figura 11. Grafico Q-Q de humedad.

Fuente: Elaboración propia.

La figura 12, muestra unos datos altos de humedad.




Figura 12. Histograma de humedad sin transformar.

Fuente: Elaboración propia.

La variable humedad se transforma con la función $\ln(x)$ para que los datos se ajusten a una distribución normal (ve figura 13). Los resultados obtenidos se reconvierten para expresarlos en las unidades correctas.




Figura 13. Grafico Q-Q de humedad transformada.

Fuente: Elaboración propia.

5.2.2 Análisis de anisotropías.

El manto AB tiene un rumbo en a la zona de estudio de 36° y buzamiento general de 14° , se analizaron anisotropías para cada variable resumidas en la figura 14, 15 y 16. En los mapas variograficos y para determinar la direccion de anisotropia que prenomina para cada variable se escoge la de menos efecto pepita. Solo se analizo el caso 2D porque la relacion de la variable entre su extension y espesor del manto hace que no sea relevante estudiar la variacion en la vertical.

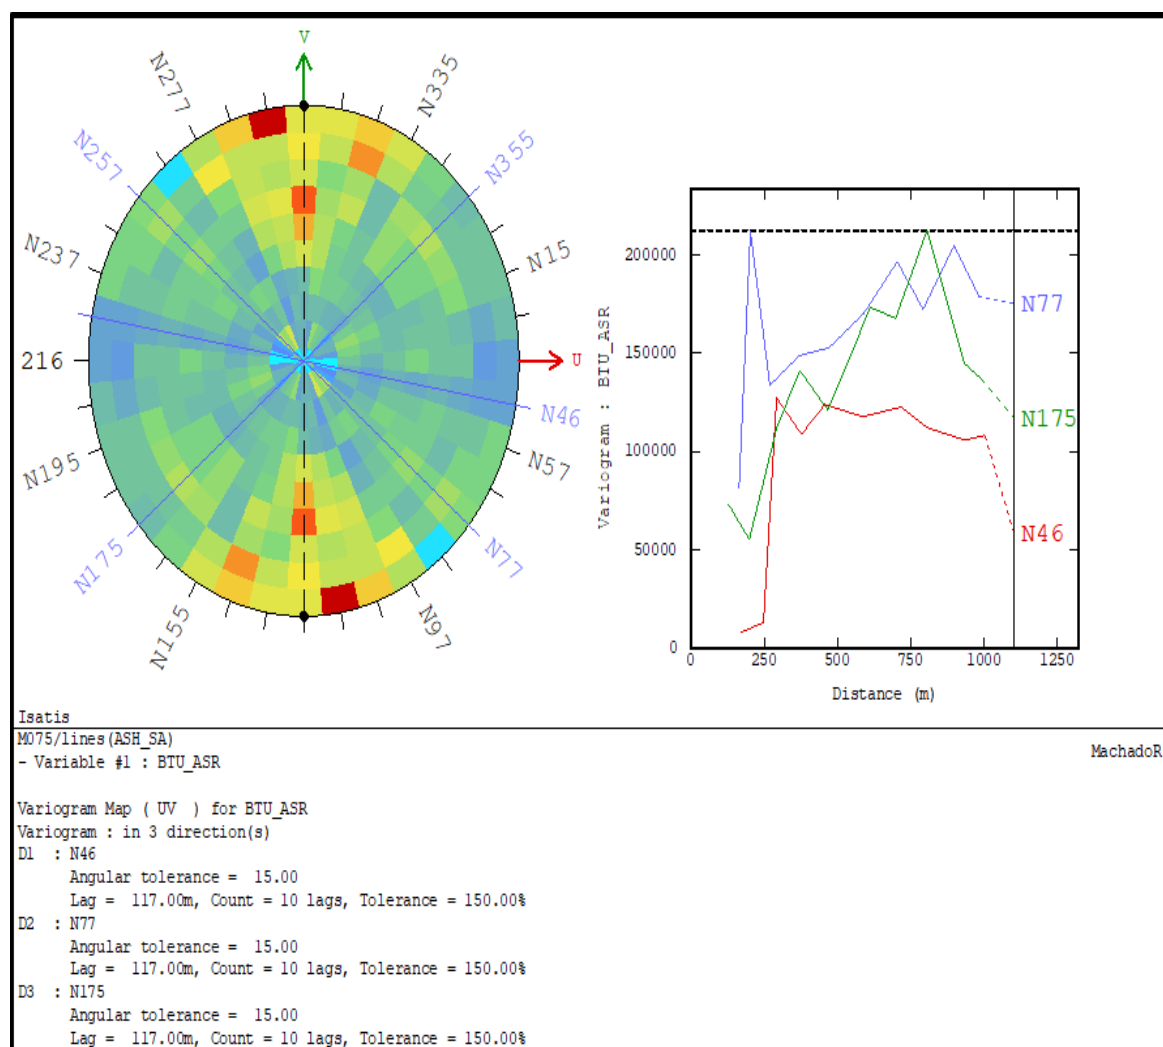


Figura 14. Análisis de la anisotropía de la variable poder calorífico.

Fuente: Elaboración propia.

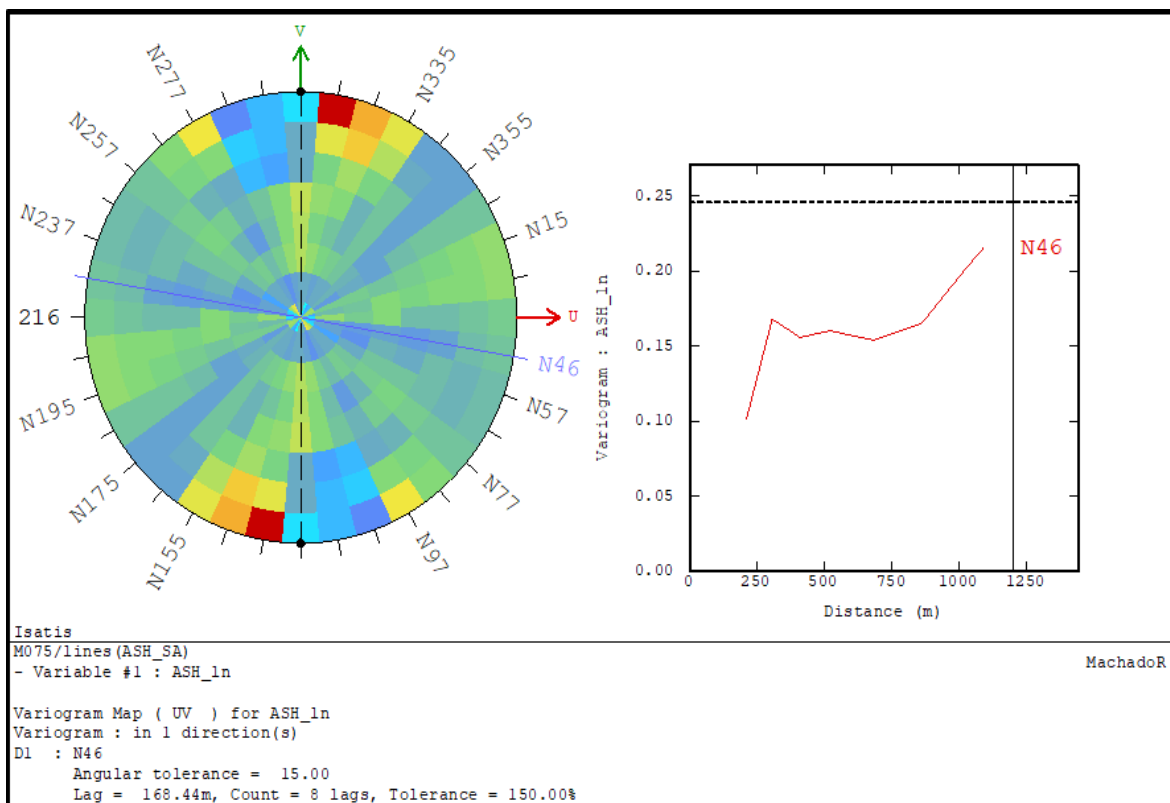


Figura 15. Análisis de la anisotropía de la variable ceniza.

Fuente: Elaboración propia.

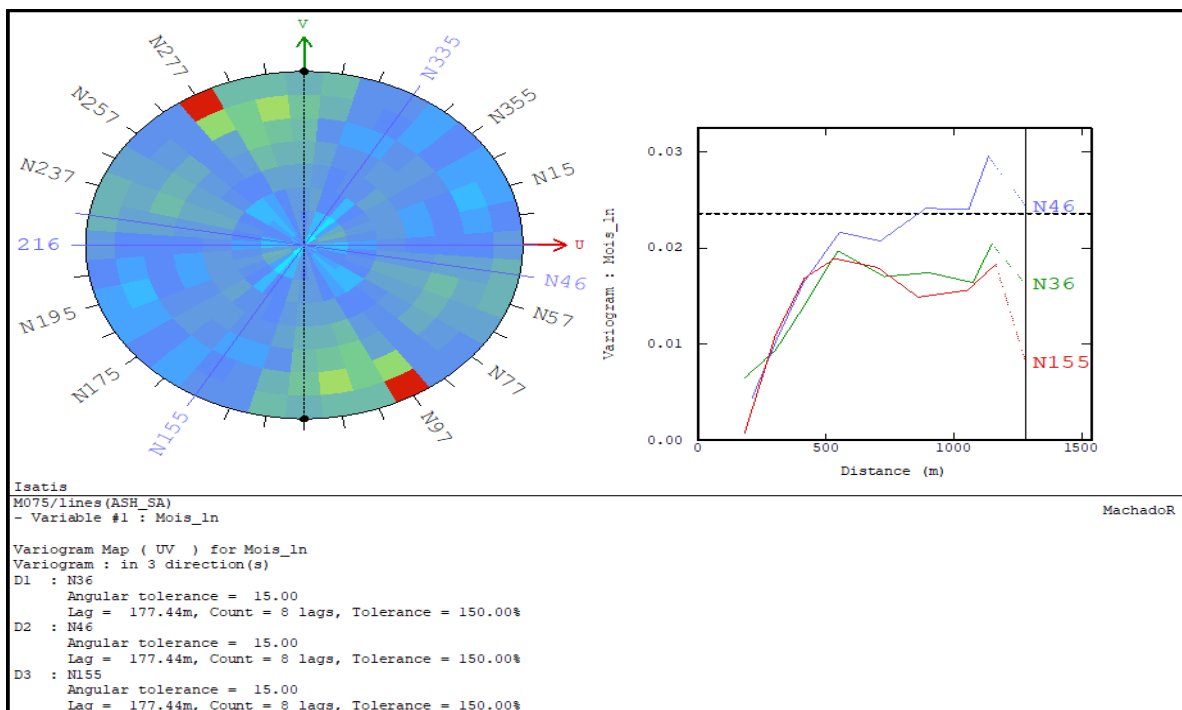


Figura 16. Análisis de la anisotropía de la variable humedad.

Fuente: Elaboración propia.

Las direcciones de anisotropía para cada variable son:

- Poder calorífico: Dirección N46
- Ceniza: Dirección N46
- Humedad: Dirección N65

El tipo de anisotropía para cada variable según la dirección se define en el variograma.

5.2.3 Variograma.

A continuación, se presentan los variogramas experimentales y teóricos ajustados para la dirección N46 para BTU y ASH, además se incluyó la dirección N136 porque representa a menor continuidad. Para la variable humedad(MOI_In) la dirección de mayor continuidad es N65 y menor en N155.

El variograma experimental de poder calorífico (ver figura 17) corresponde a una anisotropía zonal y se ajustó a un modelo exponencial. La validación cruda se puede observar en la figura 18 y en la tabla 3 se observan los datos de la varianza del error estandarizada y la cantidad de datos rechazados es de 3.




Figura 17. Variograma experimental y teóricos ajustados poder calorífico.

Fuente: Elaboración propia




Figura 18. Validación cruzada de poder calorífico.

Fuente: Elaboración propia

	Base			Ejecutados		
	Datos	Media	Varianza	Datos	Media	Varianza
Error	55,00	-72,65824	120824,48691	52,00	-72,65824	120824,48691
Std. Error		-0,17811	0,81927		-0,17811	0,81927

Tabla 3. Resultado de la validación de poder calorífico.

La variable cenizas se ajusto el variograma experimental (figura 19) en la direccion N46 a un modelo exponencial y se observa una anisotropia geometria y el resultado de la validación se observa en la figura 20 y en la tabla 4 los resultados de la varianza del error estandarizado y los datos rechazados son 4 y se acepta este ajsute dado que la base de datos es pequeña.




Figura 19. Variograma experimental y teóricos ajustados ceniza.

Fuente: Elaboración propia

	Base			Ejecutados		
	Datos	Media	Varianza	Datos	Media	Varianza
Error	57,00	-0,03931	0,28416	53,00	0,03903	0,14994
Std. Error		-0,08801	1,85417		0,08801	0,97372

Tabla 4. Resultado de la validación de ceniza.

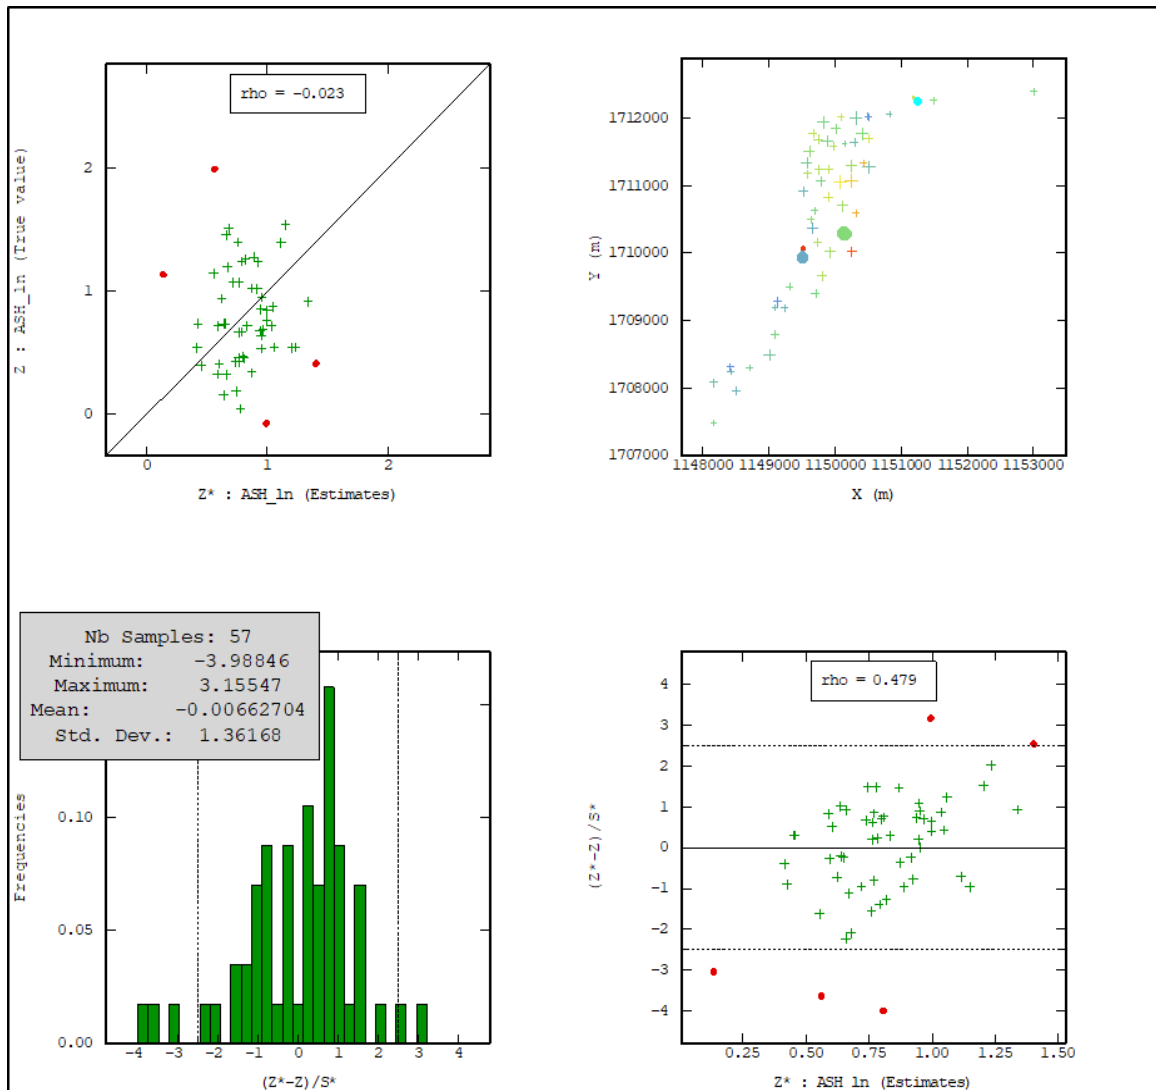


Figura 20. Validación cruzada de ceniza transformada.

Fuente: Elaboración propia

Para la humedad, la dirección de anisotropía es N65 y ajuste a un variograma teórico exponencial (figura 21) con anisotropía geométrica y el resultado de la validación del modelo tabla 5 y en la figura 22. Los datos rechazados son 4 y se acepta este ajuste dado que la base de datos es pequeña.




Figura 21. Variograma experimental y teóricos ajustados humedad transformada.

Fuente: Elaboración propia

	Base			Ejecutados		
	Datos	Media	Varianza	Datos	Media	Varianza
Error	58,00	-0,00141	0,02583	54,00	0,01623	0,01199
Std. Error		-0,00576	1,59067		0,12790	0,81299

Tabla 5. Resultado de la validación de humedad.

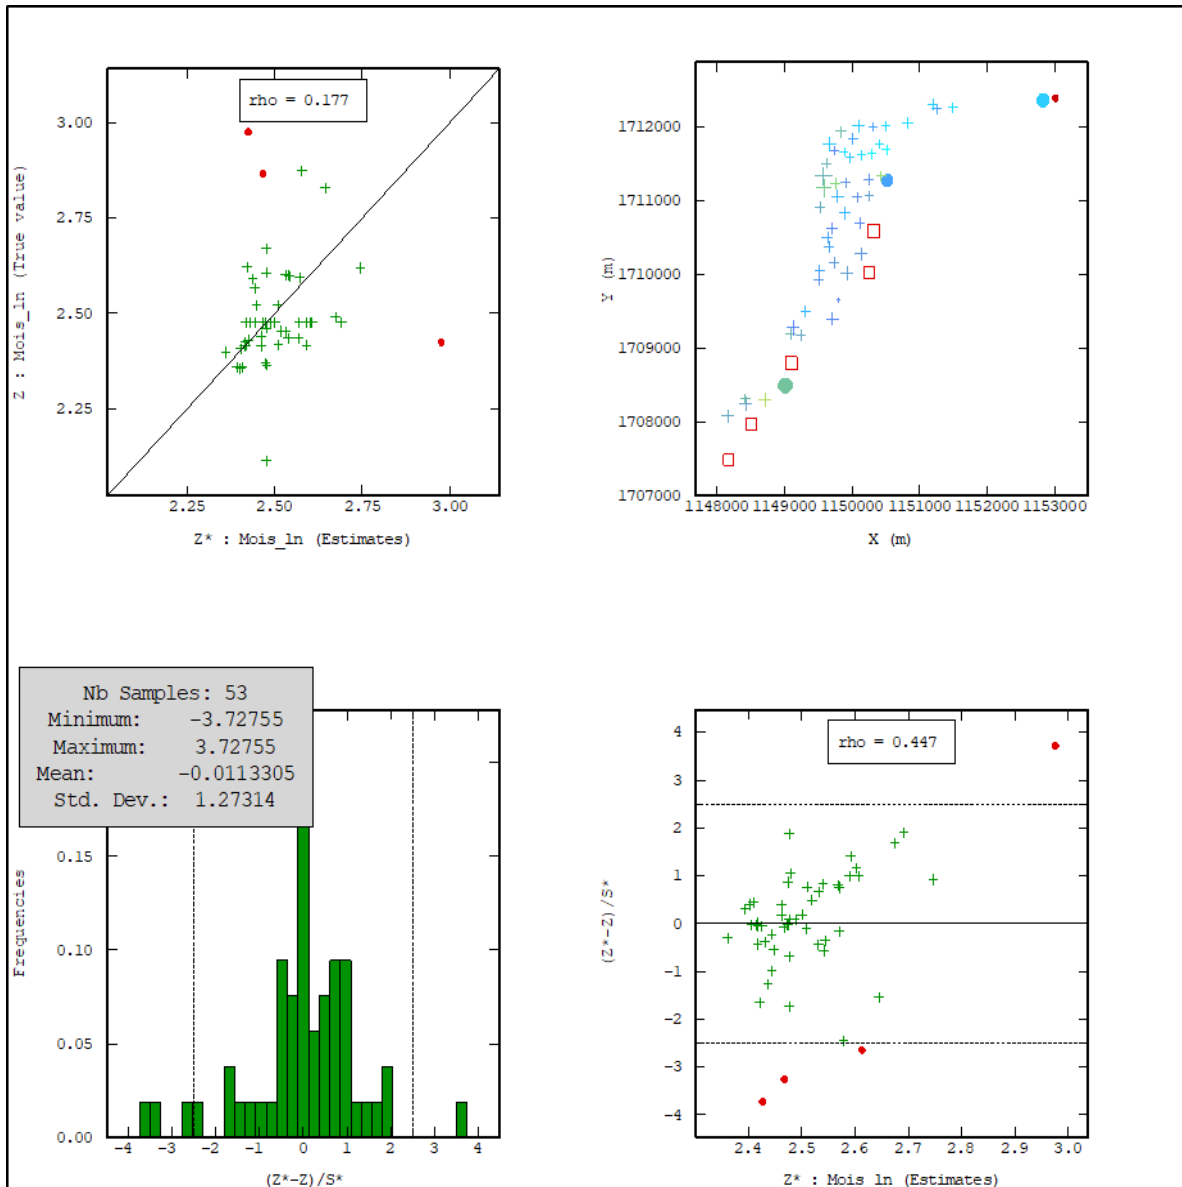


Figura 22. Validación cruzada.

Fuente: Elaboración propia

5.2.4 Estimación

La malla de estimación definida es 100m x 100m, se ajustó de tal forma que garantice todos los datos.

Para todas las variables de calidad se va a estimar por inverso de la distancia al cuadrado (método de estimación actual) y kriging Ordinario de Bloques. Además, se analizó la variable BTU con simulación secuencial gaussiano.

5.2.4.1 Inverso de la distancia al cuadrado.

Para la variable poder calorífico se observan los mayores valores en el área norte (figura 23), los focos de valores intermedios coinciden con los valores altos visualizados en la representación de la humedad en la figura 25.




Figura 23. Inverso de la distancia al cuadrado de poder calorífico.

Fuente: Elaboración propia

El comportamiento de las cenizas es homogéneo no se observan en la figura 24 focos o concentraciones relevantes.




Figura 24. Inverso de la distancia de ceniza.

Fuente: Elaboración propia




Figura 25. Inverso de la distancia de humedad.

Fuente: Elaboración propia.

5.2.4.2 Kriging Ordinario de Bloques.

La figura 26 muestra el resultado de la estimación por kriging del poder calorífico, se observan focos del orden de 11500 Btu/b, pero la transición entre estos es suavizada




Figura 26. Estimación de poder calorífico por kriging ordinario.

Fuente: Elaboración propia.

Las figuras 27 y 28 muestran que donde tienen mayor concentración coinciden con las zonas de menos poder calorífico.




Figura 27. Estimación de ceniza kriging lognormal.

Fuente: Elaboración propia.




Figura 28. Estimación de humedad por kriging lognormal.

Fuente: Elaboración propia.

5.2.4.3 Simulación Secuencial Gaussiano.

A. Transformación Gaussiana.

Para llevar a cabo la simulación se hizo la transformación de los datos de calidad BTU y los datos resumidos en la figura 29 corresponden a los coeficientes normalizados.

	0	1	2	3	4
0+	12337.299	-402.925	-183.836	-54.612	46.180
5+	70.624	6.035	-44.094	-22.508	19.176
10+	23.866	-2.726	-19.643	-6.212	14.186
15+	10.024	-9.281	-10.833	5.464	10.138
20+	-2.713	-8.860	0.801	7.485	0.525
25+	-6.216	-1.474	5.100	2.187	-4.104

Figura 29. Coeficientes normalizados del polinomio de hermita.

B. Variograma.

La figura 30 muestra claramente el comportamiento gaussiano de la variable transformada, con media 0.




Figura 30. Histograma de poder calorífico normalizado.

Se ajusto el variograma experimental de la variable transformada a un modelo exponencial y en las direcciones de anisotropías definidas anteriormente N46 y N136(ver figura 31). Se identifica un tipo de anisotropía zonal.




Figura 31. Variograma teórico ajustado de poder calorífico gaussiano.

Fuente: Elaboración propia.

C. Secuencial Gaussian

Para la simulación se realizaron en total 100 iteraciones y el resultado de la media se observan en la figura 32.




Figura 32. Simulación secuencial gaussiana de poder calorífico.

Fuente: Elaboración propia.

5.2.5 Comparación entre los métodos de estimación de calidad.

Para tener una aproximación del método que refleje mejor los datos estudiados se hizo una tabla de comparación (ver tabla 6) y se encontró que con simulación condicional gaussiana se obtiene la mejor representación de los datos de poder calorífico con una desviación con respecto al dato real de 0,8%. El dato real fue ajustado con el mismo factor de los datos del estudio y el valor no corresponde a todo a la extracción del manto AB, pero nos sirve para identificar a cuál modelo de estimación se asemeja más.

COMPARACION DE PODER CALORIFÍCO - AREA MINADA		
Real	12.046	DIF
Inverso de la distancia al cuadrado	12.219	1,40%
Kriging ordinario de bloques	12.342	2,50%
Secuencial condicional gaussiano	12.144	0,80%

Tabla 6. comparación de resultados de estimaciones de poder calorífico.

Fuente. Elaboración propia.

La figura 33, muestra el comportamiento del poder calorífico de acuerdo a cada técnica estimada. Se puede observar la curva de la simulación que tiene un comportamiento completamente diferente al de inverso de la distancia al cuadrado y kriging ordinario de bloque, es decir, esto demuestra que esta curva representa mejor la variabilidad del depósito. Con respecto al kriging ordinario de bloques se observa que este tiende a suavizar el comportamiento con respecto al inverso de la distancia al cuadrado.




Figura 33. Grado-proporción del poder calorífico para los diferentes métodos de estimación.

5.3 Recursos In situ:

Para estimar Recursos In Situ es importante conocer el buzamiento del manto y el espesor, para comparar los métodos de estimación se asume buzamiento constante y la variable crítica espesor (TT).

5.3.1 Análisis exploratorio de datos

La tabla 7, figura 34 y 35 resumen el análisis exploratorio de datos donde muestra la tendencia de normalidad, en la gráfica Q-Q y una relación de mediana/media de 95,7%.

ESTADISTICA BASICA - Espesor MANTO									
Cantidad	Amplitud		Tendencia Central			Variabilidad		Estructura	
	Minimo	Maximo	Media	Mediana	Varianza	viación Estan	Variat.C	Skewness=0	Kurtosis=3
59	1,3	7,66	4,16	3,98	0,82	0,9	0,22	0,92	6,87

Tabla 7. Estadística básica.




Figura 34. Histograma de espesor normalizado.

Fuente: Elaboración propia




Figura 35. Grafica Q-Q de espesor normalizado.

Fuente: Elaboración propia

5.3.2 Variograma

Se realizó el análisis Variográfico para determinar la dirección de anisotropía que corresponde a N46 (ver figura 36).

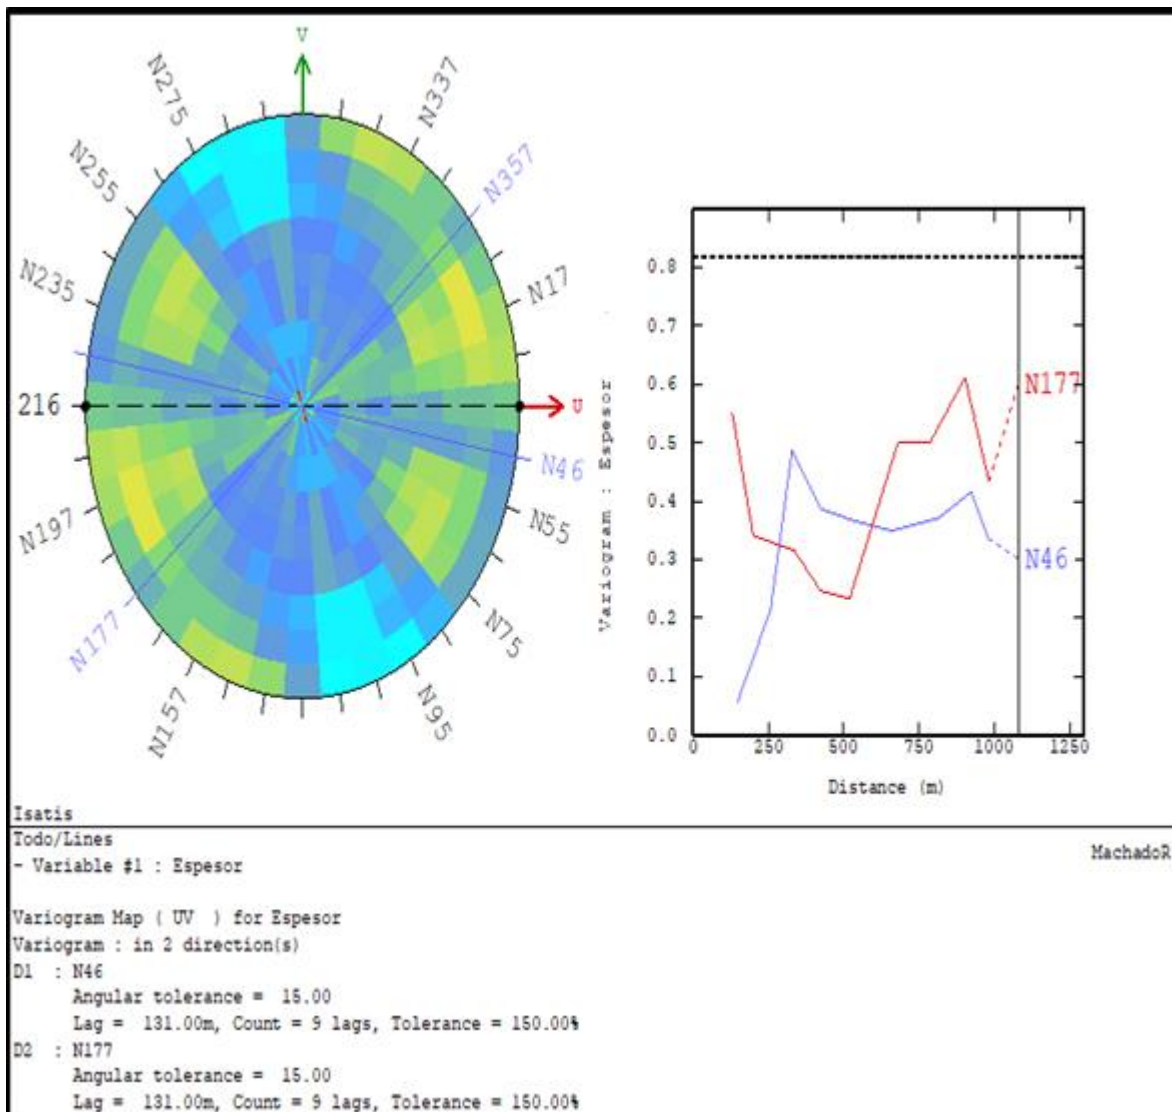


Figura 36. Análisis Variográfico de espesor.

Fuente: Elaboración propia

El variograma experimental en la dirección N46 presenta una anisotropía zonal, este variograma se ajustó a un modelo teórico exponencial (ver figura 37) y se realizó la validación cruzada con resultados resumidos en la Tabla 8 y figura 38, los datos rechazados fueron 3.




Figura 37. Variograma experimental ajustado de espesor MAB.

Fuente: Elaboración propia

	Base			Ejecutados		
	Datos	Media	Varianza	Datos	Media	Varianza
Error	55,00	0,01628	0,28224	52,00	-0,01628	0,14185
Std. Error		0,02711	1,18017		-0,02317	0,38204

Tabla 8. Resultado de la validación de espesor.

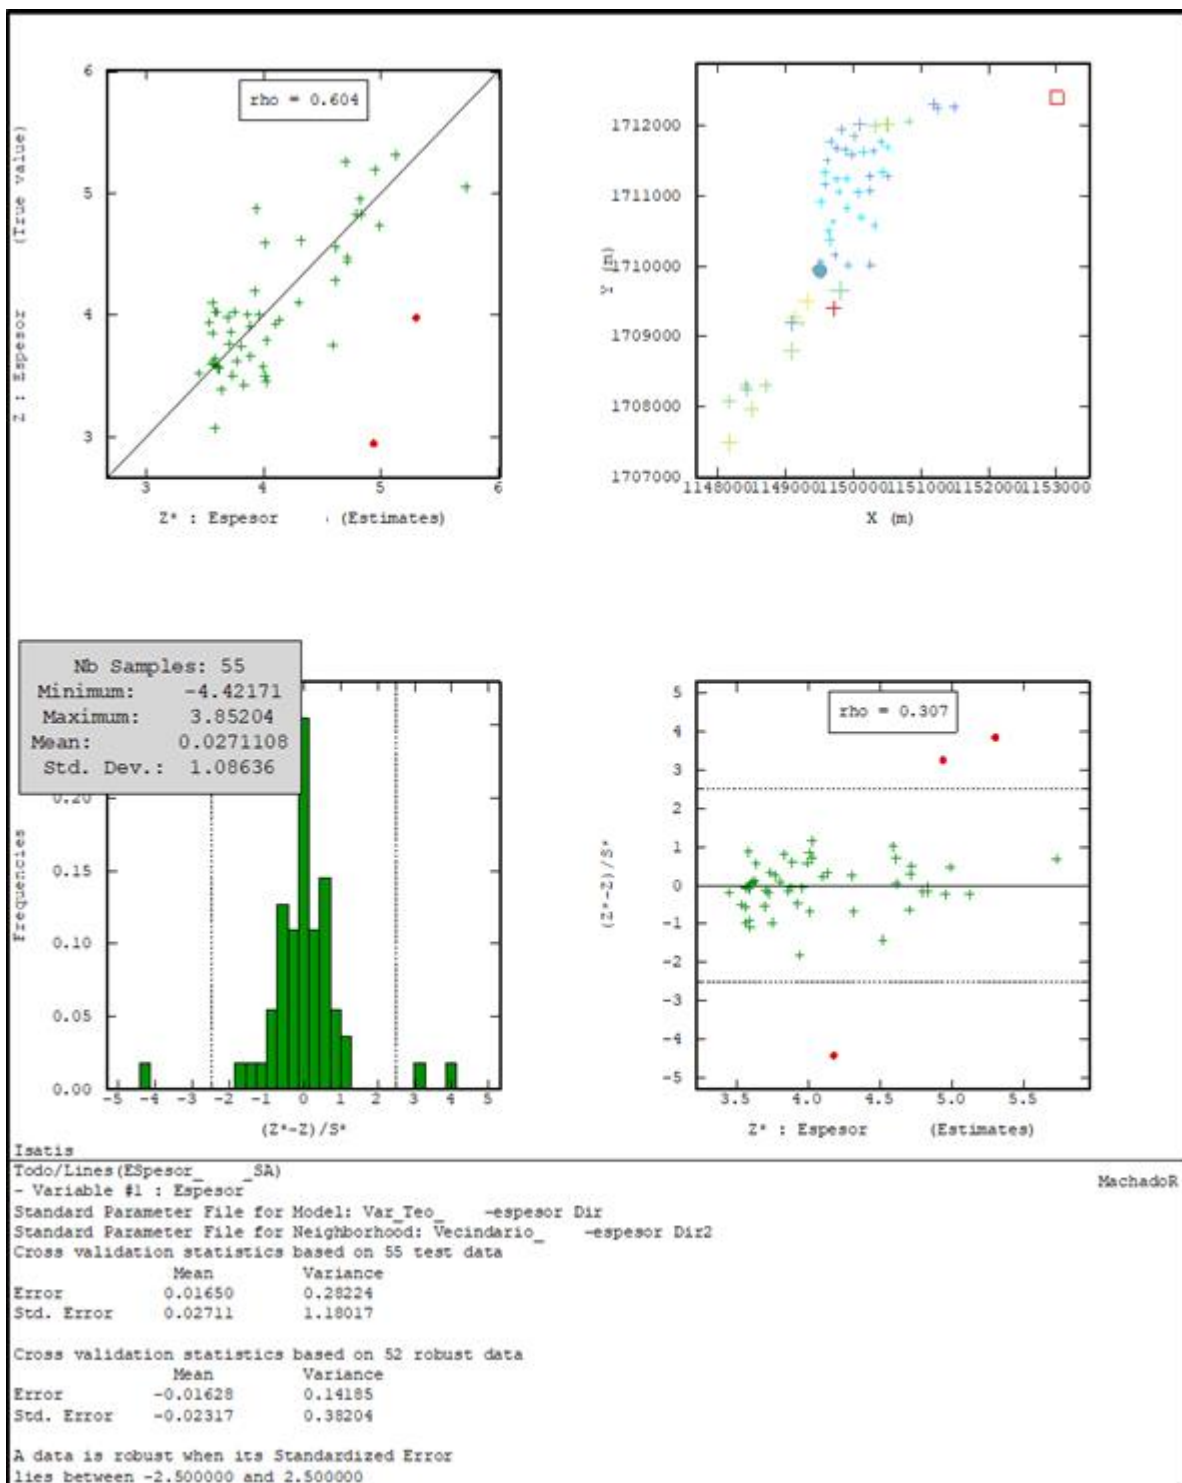


Figura 38. Validación cruzada del modelo teórico para la variable espesor.

Fuente: Elaboración propia

5.3.3 Estimación.

5.3.3.1 Inverso de la distancia.

La figura 39 es el resultado de la estimación por inverso de la distancia, se ve un espesor homogéneo que oscila entre 1,3m y 7,66m con promedio de 4,43m.




Figura 39. Estimación del espesor por inverso de la distancia al cuadrado.

Fuente: Elaboración propia

5.3.3.2 Kriging Ordinario de Bloques

La estimación por este método es más suavizada, el espesor oscila entre 2,95m y 5,74m con valor promedio 4,26(ver figura 40).




Figura 40. Estimación de espesor por kriging ordinario.

Fuente: Elaboración propia

Para estimar el espesor por intervalos de confianza se deben transformar los datos a gaussiano y luego usar el método.

Anamorfosis Gaussiana.

El polinomio de hermita para transformar los datos a gaussianos (ver figura 41).

	0	1	2	3	4
0+	4.104	-0.607	0.124	0.033	-0.073
5+	0.020	0.042	-0.013	-0.022	0.001
10+	0.009	0.006	-0.003	-0.008	-0.001
15+	0.006	0.002	-0.001	-0.002	-0.003
20+	0.002	0.008	-0.002	-0.011	0.001
25+	0.013	-0.001	-0.014	0.001	0.014

Figura 41. Polinomio de hermita de la variable espesor gaussiano.

El histograma muestra que el dato transformado corresponde a una distribución normal estándar con media 0 (ver figura 42).




Figura 42. Histograma de la variable espesor gaussiano.

En la figura 43 se observa el ajuste del variograma experimental a un variograma teórico exponencial en las direcciones N46y N136.




Figura 43. Variograma teórico ajustado de la variable espesor gaussiano.

Fuente: Elaboración propia.

Estimación

Al aplicar el método de intervalos de confianza se obtienen 3 escenarios: ideal (figura 44), optimista (figura 45) y pesimista (figura 46).

La estimación del escenario ideal del intervalo de confianza oscila entre valores 2,46m y 6,89m con un espesor promedio de 4,26m.




Figura 44. Estimación de espesor por intervalos de confianza ideal.

La estimación del escenario optimista del intervalo de confianza oscila entre valores 2,91m y 7,66m con un espesor promedio de 5,54m.




Figura 45. Estimación de espesor por intervalos de confianza caso optimista.

La estimación del escenario pesimista del intervalo de confianza oscila entre valores 1,58m y 6,36m con un espesor promedio de 3,53m.




Figura 46. Estimación de espesor por intervalos de confianza caso pesimista.

5.3.4 Comparación entre los métodos de estimación de Recursos In Situ

Para espesores mayores a 4m (ver figura 47) el método de inverso a distancia al cuadrado es más optimista que el caso ideal de inverso de la distancia esto puede llevar a sobre estimaciones que afectan el índice de recuperación de carbón o en otras palabras puede llevar a sobre estimar recursos recuperables. La zona más crítica o de mayor riesgo de sobreestimación está en espesores de iguales o superiores a 5,5m.

La estimación por intervalos de confianza permite cuantificar los recursos recuperables con mayor precisión, ese el objetivo de la minería actual que busca minimizar la incertidumbre geológica para hacer planes de extracción con mayor probabilidad de cumplir.




Figura 47. Comparación entre métodos de estimación.

Fuente: Elaboración propia.

6.CONCLUSIONES

- La comparación de los métodos tradicionales y los geoestadístico utilizados en la estimación del poder calorífico y basado en los resultados obtenidos por cada método de estimación: inverso de la distancia al cuadrado, kriging ordinario de bloques y la simulación condicional gaussiana al conciliarlos con los datos reales.
- En el caso del análisis de la variable espesor, se puede concluir que los métodos geoestadísticos tienen menor incertidumbre y para la planeación minera es de gran importancia, ya que hay mayor confiabilidad en los resultados obtenidos.
- La simulación geoestadística por el método secuencial gaussiano es un procedimiento de estimación confiable de las variables de calidad en el yacimiento de carbón en el tajo analizado.
- Los principales avances de investigación en la estimación de Recursos In Situ van orientados al análisis del comportamiento de los datos con el fin de obtener estimaciones más precisas. La aplicación de las metodologías implementadas en este trabajo despierta el interés en la mina el Cerrejón de aplicar la geoestadística.

7. RECOMENDACIONES

- Para aplicar la geoestadística a los depósitos de carbón se puede simplificar con un análisis bidimensional por la relación extensión versus espesor del manto.
- El estudio de la minería del carbón debe hacerse manto a manto para estudiar cada variable que tienen comportamiento diferentes como buzamiento, espesor, entre otros.
- Se debe hacer el ejercicio para mantos afectados con fallamiento geológico.

8. BIBLIOGRAFÍA

- Cerrejon. (2017). Cerrejon. Retrieved November 24, 2017, from <http://www.cerrejon.com>
- Díaz Viera, M. A. Geoestadística aplicada, Instituto de Geofísica, UNAM ,Instituto de Geofísica y Astronomía, CITMA, Cuba 144 (2002).
- Emery, X. (2007). *Apuntes de geoestadística*. Retrieved from <https://www.u-cursos.cl>
- Ersoy, A., & Yünsel, T. Y. (2006). Geostatistical Conditional Simulation for the Assessment of the Quality Characteristics of Cayırhan Lignite Deposits. *Energy, Exploration & Exploitation*, 24(6), 391–416. <http://doi.org/10.1260/014459806780796312>
- Ertunç, G., Tercan, A. E., Hindistan, M. A., Ünver, B., Ünal, S., Atalay, F., & Killioğlu, S. Y. (2013). Geostatistical estimation of coal quality variables by using covariance matching constrained kriging. *International Journal of Coal Geology*, 112, 14–25. <http://doi.org/10.1016/j.coal.2012.11.014>
- Isabel, R. B. G. (2010). *Aplicación del método del intervalo de confianza como técnica geoestadística no lineal a la modelación espacial de variables geotécnicas*. Universidad Nacional de Colombia Facultad - Sede Medellín.
- Nur, M., & Koike, K. (2008a). Identifying spatial heterogeneity of coal resource quality in a multilayer coal deposit by multivariate geostatistics, 73, 307–330. <http://doi.org/10.1016/j.coal.2007.07.005>
- Nur, M., & Koike, K. (2008b). International Journal of Coal Geology Uncertainty assessment of coal tonnage by spatial modeling of seam distribution and coal quality, 76, 217–226. <http://doi.org/10.1016/j.coal.2008.07.014>
- Olea, R. A., & Luppens, J. A. (2015). International Journal of Coal Geology Mapping of coal quality using stochastic simulation and isometric logratio transformation with an application to a Texas lignite, 152, 80–93.
- Pardo-Igúzquiza, E., Dowd, P. A., Baltuille, J. M., & Chica-Olmo, M. (2013). Geostatistical modelling of a coal seam for resource risk assessment. *International Journal of Coal Geology*, 112, 134–140. <http://doi.org/10.1016/j.coal.2012.11.004>
- Roth, C., & Armstrong, M. (n.d.). Confidence Intervals for Local Estimation Application to the Witwatersrand Basin. Centre de Geostatistique, France.
- Tercan, A. E., & Ihsan, A. (2001). Estimation of lignite reserve in the Kalburcayiri field , Kangal basin , Sivas , Turkey.
- Tercan, A. E., & Sohrabian, B. (2013). International Journal of Coal Geology Multivariate geostatistical simulation of coal quality data by independent components. *International Journal of Coal Geology*, 112, 53–66. <http://doi.org/10.1016/j.coal.2012.10.007>
- Webster, R., & Oliver, M. A. (2008). *Geostatistics for Environmental Scientists: Second Edition*. (U. Senn, Stephen (University of Glasgow & U. Scott, Marion(University of Glasgow, Eds.)*Geostatistics for Environmental Scientists: Second Edition* (John Wiley). <http://doi.org/10.1002/9780470517277>